


# Poisson-eloszlás paraméterének becslése (4. előadás)



A gólok számának hisztogramja  $n = 95$  mérkőzésen, és különböző paraméterű Poisson-eloszlások ( $\mathbb{P}_\lambda(X = k) = \lambda^k / k! \cdot e^{-\lambda}$ )

## Poisson-eloszlás paraméterének becslése

Tegyük fel, hogy  $X_1, X_2, \dots, X_n$  független, azonos  $\lambda$  paraméterű Poisson-eloszlású minta, ahol  $\lambda > 0$  ismeretlen paraméter,  $n = 95$ , és  $\bar{X} = 1,379$ .

Poisson-eloszlásnál:

$$\mathbb{P}_\lambda(X_j = k) = \frac{\lambda^k}{k!} e^{-\lambda}; \quad \mathbb{E}(X_j) = \lambda; \quad D(X_j) = \sqrt{\lambda}.$$


A megfigyelések az alábbiak (a gólok száma összesen  $\sum_{j=1}^n X_j = 131$ ):

$$3, \quad 0, \quad 2, \quad 2, \quad 1, \quad 3, \dots, 2.$$

Annak valószínűsége  $\lambda$  paraméter mellett, hogy éppen ezt a sorozatot kaptuk:

$$\begin{aligned} L_{95,\lambda}(3, 0, 2, \dots, 2) &= \frac{\lambda^3}{3!} e^{-\lambda} \cdot \frac{\lambda^0}{0!} e^{-\lambda} \cdot \frac{\lambda^2}{2!} e^{-\lambda} \cdot \dots \cdot \frac{\lambda^2}{2!} e^{-\lambda} = \\ &= \frac{\lambda^{3+0+2+\dots+3}}{3! \cdot 0! \cdot 2! \cdot \dots \cdot 2!} e^{-95 \cdot \lambda} = \frac{\lambda^{131}}{3! \cdot 0! \cdot 2! \cdot \dots \cdot 2!} e^{-95 \cdot \lambda} \end{aligned}$$

# Poisson-eloszlás paraméterének becslése



A  $\frac{\lambda^{131}}{3! \cdot 0! \cdot 2! \cdot \dots \cdot 2!} e^{-95 \cdot \lambda}$  likelihoodfüggvény a  $\lambda > 0$  paraméter függvényében;

mintaátlag:  $\bar{X} = \frac{131}{95} = 1,379$

## ML-becslés: Poisson-eloszlás

$X_1, \dots, X_n$  függetlenek, Poisson-eloszlás  $\lambda > 0$  ismeretlen paraméterrel, azaz

$$\mathbb{P}(X_j = k) = \frac{\lambda^k}{k!} e^{-\lambda} \quad (k = 0, 1, 2, \dots).$$

Ekkor

$$L_{n,\lambda}(X_1, \dots, X_n) = \prod_{j=1}^n \left( \frac{\lambda^{X_j}}{X_j!} e^{-\lambda} \right) = \frac{\lambda^{X_1}}{X_1!} e^{-\lambda} \cdot \frac{\lambda^{X_2}}{X_2!} e^{-\lambda} \cdot \dots \cdot \frac{\lambda^{X_n}}{X_n!} e^{-\lambda}.$$

$$L_{n,\lambda}(X_1, \dots, X_n) = \lambda^{\sum_{j=1}^n X_j} e^{-n\lambda} \cdot \prod_{j=1}^n \frac{1}{X_j!}.$$

## ML-becslés: Poisson-eloszlás

$X_1, \dots, X_n$  függetlenek, Poisson-eloszlás  $\lambda > 0$  ismeretlen paraméterrel, azaz

$$\mathbb{P}(X_j = k) = \frac{\lambda^k}{k!} e^{-\lambda} \quad (k = 0, 1, 2, \dots).$$

Ekkor

$$L_{n,\lambda}(X_1, \dots, X_n) = \prod_{j=1}^n \left( \frac{\lambda^{X_j}}{X_j!} e^{-\lambda} \right) = \frac{\lambda^{X_1}}{X_1!} e^{-\lambda} \cdot \frac{\lambda^{X_2}}{X_2!} e^{-\lambda} \cdot \dots \cdot \frac{\lambda^{X_n}}{X_n!} e^{-\lambda}.$$

$$L_{n,\lambda}(X_1, \dots, X_n) = \lambda^{\sum_{j=1}^n X_j} e^{-n\lambda} \cdot \prod_{j=1}^n \frac{1}{X_j!}.$$

$$\log L_{n,\lambda}(X_1, \dots, X_n) = \log \lambda \sum_{j=1}^n X_j - n\lambda - \log \prod_{j=1}^n \frac{1}{X_j!}$$

## ML-becslés: Poisson-eloszlás

$X_1, \dots, X_n$  függetlenek, Poisson-eloszlás  $\lambda > 0$  ismeretlen paraméterrel, azaz

$$\mathbb{P}(X_j = k) = \frac{\lambda^k}{k!} e^{-\lambda} \quad (k = 0, 1, 2, \dots).$$

Ekkor

$$L_{n,\lambda}(X_1, \dots, X_n) = \prod_{j=1}^n \left( \frac{\lambda^{X_j}}{X_j!} e^{-\lambda} \right) = \frac{\lambda^{X_1}}{X_1!} e^{-\lambda} \cdot \frac{\lambda^{X_2}}{X_2!} e^{-\lambda} \cdot \dots \cdot \frac{\lambda^{X_n}}{X_n!} e^{-\lambda}.$$

$$L_{n,\lambda}(X_1, \dots, X_n) = \lambda^{\sum_{j=1}^n X_j} e^{-n\lambda} \cdot \prod_{j=1}^n \frac{1}{X_j!}.$$

$$\log L_{n,\lambda}(X_1, \dots, X_n) = \log \lambda \sum_{j=1}^n X_j - n\lambda - \log \prod_{j=1}^n \frac{1}{X_j!}$$

$$\frac{\partial}{\partial \lambda} \log L_{n,\lambda}(X_1, \dots, X_n) = \frac{\sum_{j=1}^n X_j}{\lambda} - n > 0 \Leftrightarrow \lambda < \bar{X}.$$

Ezért az ML-becslés:  $\hat{\lambda} = \bar{X}$ , mivel a derivált itt vált előjelet.

# Maximumlikelihood-módszer

## Definíció (Likelihood-függvény)

Ha az  $(Y_1, \dots, Y_n)$  független minta diszkrét (a lehetséges értékeinek száma véges vagy megszámlálható sok), akkor a likelihood-függvénye:

$$L_{n,\vartheta}(k_1, \dots, k_n) = \prod_{j=1}^n \mathbb{P}_{j,\vartheta}(Y_j = k_j) \quad ((k_1, \dots, k_n) \in H).$$

# Maximumlikelihood-módszer

## Definíció (Likelihood-függvény)

Ha az  $(Y_1, \dots, Y_n)$  független minta diszkrét (a lehetséges értékeinek száma véges vagy megszámlálható sok), akkor a likelihood-függvénye:

$$L_{n,\vartheta}(k_1, \dots, k_n) = \prod_{j=1}^n \mathbb{P}_{j,\vartheta}(Y_j = k_j) \quad ((k_1, \dots, k_n) \in H).$$

Ha az  $(Y_1, \dots, Y_n)$  független minta abszolút folytonos, és  $Y_j$  sűrűségfüggvénye (a  $\mathbb{P}_\vartheta$  valószínűség mellett)  $f_{j,\vartheta}$ , akkor a minta likelihood-függvénye:

$$L_{n,\vartheta}(t_1, \dots, t_n) = \prod_{j=1}^n f_{j,\vartheta}(t_j) \quad (t_1, \dots, t_n \in \mathbb{R}).$$

# Maximumlikelihood-módszer

Legyen  $(\Omega, \mathcal{A}, \mathbb{P})$  statisztikai mező, ahol  $\mathcal{P} = \{\mathbb{P}_\vartheta : \vartheta \in \Theta\}$ , vagyis az ismeretlen eloszlás a  $\vartheta$  paraméterrel jellemezhető.

## Definíció (Maximum-likelihood becslés)

A  $\vartheta$  maximumlikelihood-becslése (ML-becslése) az  $X_1, \dots, X_n$  mintából  $\hat{\vartheta}$ , ha maximalizálja a  $\vartheta \mapsto L_{n,\vartheta}(X_1, \dots, X_n)$  függvényt, ahol  $L_{n,\vartheta}$  a minta likelihood-függvénye. Azaz, ha

$$L_{n,\hat{\vartheta}}(X_1, \dots, X_n) \geq L_{n,\vartheta}(X_1, \dots, X_n) \text{ minden } \vartheta \in \Theta\text{-ra.}$$

## ML-becslés: normális eloszlás

$X_1, \dots, X_n$  függetlenek, eloszlásuk normális eloszlás  $m, \sigma > 0$  paraméterekkel. Ekkor

$$L_{n,m,\sigma}(X_1, \dots, X_n) = \prod_{j=1}^n f_{j,\vartheta}(X_j) = \prod_{j=1}^n \left[ \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(X_j - m)^2}{2\sigma^2}\right) \right].$$

## ML-becslés: normális eloszlás

$X_1, \dots, X_n$  függetlenek, eloszlásuk normális eloszlás  $m, \sigma > 0$  paraméterekkel. Ekkor

$$L_{n,m,\sigma}(X_1, \dots, X_n) = \prod_{j=1}^n f_{j,\vartheta}(X_j) = \prod_{j=1}^n \left[ \frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{(X_j - m)^2}{2\sigma^2}\right) \right].$$

$$L_{n,m,\sigma}(X_1, \dots, X_n) = \left(\frac{1}{\sqrt{2\pi\sigma}}\right)^n \exp\left(-\sum_{j=1}^n \frac{(X_j - m)^2}{2\sigma^2}\right).$$

## ML-becslés: normális eloszlás

$X_1, \dots, X_n$  függetlenek, eloszlásuk normális eloszlás  $m, \sigma > 0$  paraméterekkel. Ekkor

$$L_{n,m,\sigma}(X_1, \dots, X_n) = \prod_{j=1}^n f_{j,\vartheta}(X_j) = \prod_{j=1}^n \left[ \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(X_j - m)^2}{2\sigma^2}\right) \right].$$

$$L_{n,m,\sigma}(X_1, \dots, X_n) = \left(\frac{1}{\sqrt{2\pi}\sigma}\right)^n \exp\left(-\sum_{j=1}^n \frac{(X_j - m)^2}{2\sigma^2}\right).$$

$$\log L_{n,m,\sigma}(X_1, \dots, X_n) = -n \log(\sqrt{2\pi}) - n \log \sigma - \sum_{j=1}^n \frac{(X_j - m)^2}{2\sigma^2}.$$

Rögzített  $\sigma$  mellett ez akkor maximális, ha  $\sum_{j=1}^n (X_j - m)^2 = \sum_{j=1}^n X_j^2 - 2 \sum_{j=1}^n X_j m + nm^2$  minimális  $\Rightarrow \hat{m} = \bar{X}$ .

## ML-becslés: normális eloszlás

$$\log L_{n,\sigma}(X_1, \dots, X_n) = -n \log(\sqrt{2\pi}) - n \log \sigma - \sum_{j=1}^n \frac{(X_j - \bar{X})^2}{2\sigma^2}.$$

A  $\sigma$  szerinti parciális derivált:

$$\frac{\partial}{\partial \sigma} \log L_{n,\sigma}(X_1, \dots, X_n) = -\frac{n}{\sigma} + \sum_{j=1}^n \frac{(X_j - \bar{X})^2}{\sigma^3}.$$

Ez pontosan akkor pozitív, ha  $\sigma^2 < \frac{1}{n} \sum_{j=1}^n (X_j - \bar{X})^2 = s_n^2$ .

Tehát az ML-becslés:

$$\hat{m} = \bar{X}; \quad \hat{\sigma} = s_n = \sqrt{\frac{1}{n} \sum_{j=1}^n X_j^2 - \bar{X}^2}.$$

Tehát normális eloszlásnál az  $m$  paraméter becslése a mintaátlag, a szórásé a tapasztalati szórás.

# Az ML-becslés tulajdonságai

- Nem minden statisztikai mezőn létezik ML-becslés.
- Az ML-becslés nem feltétlenül egyértelmű.
- Az ML-becslés nem feltétlenül torzítatlan.
- A  $\psi(\vartheta)$  függvény ML-becslése  $\psi(\hat{\vartheta})$ , ahol  $\hat{\vartheta}$  ML-becslés  $\vartheta$ -ra.
- **Megfelelő feltételek** (erős regularitási feltételek mellett) az ML-becslés aszimptotikusan torzítatlan, **aszimptotikusan hatásos** (vagyis minimális szórású) és **aszimptotikusan normális eloszlású**, azaz  $\sqrt{n}(\hat{\vartheta}_n - \vartheta)$  normális eloszláshoz konvergál eloszlásban  $n \rightarrow \infty$  esetén (a  $\mathbb{P}_\vartheta$  valószínűségegre vonatkozóan).
- Az alábbi egyenlet a maximumlikelihood-egyenlet:

$$\frac{\partial}{\partial \vartheta} \log L_{n,\vartheta}(X_1, \dots, X_n) = 0.$$

Megfelelő feltételek mellett az ML-becslés a maximumlikelihood-egyenlet megoldása (ha az ML-becslés nem számítható ki, de az egyenlet megoldható, gyakran az egyenlet megoldásával helyettesítik az ML-becslést).

## ML-becslés: egyenletes eloszlás

Ebben az esetben az ML-becslés nem számítható ki az ML-egyenlet gyökeként, vagyis nem kapható meg deriválással.

$X_1, \dots, X_n$  függetlenek, eloszlásuk egyenletes eloszlás az  $[a, b]$  intervallumon. Ekkor

$$L_{n,a,b}(X_1, \dots, X_n) = \prod_{j=1}^n f_{j,\vartheta}(X_j) = \prod_{j=1}^n \mathbb{I}(a \leq X_j \leq b) \cdot \frac{1}{b-a}.$$

$$L_{n,a,b}(X_1, \dots, X_n) = \left(\frac{1}{b-a}\right)^n \mathbb{I}(a \leq \min_j X_j \text{ és } \max_j X_j \leq b).$$

## ML-becslés: egyenletes eloszlás

Ebben az esetben az ML-becslés nem számítható ki az ML-egyenlet gyökeként, vagyis nem kapható meg deriválással.

$X_1, \dots, X_n$  függetlenek, eloszlásuk egyenletes eloszlás az  $[a, b]$  intervallumon. Ekkor

$$L_{n,a,b}(X_1, \dots, X_n) = \prod_{j=1}^n f_{j,\vartheta}(X_j) = \prod_{j=1}^n \mathbb{I}(a \leq X_j \leq b) \cdot \frac{1}{b-a}.$$

$$L_{n,a,b}(X_1, \dots, X_n) = \left(\frac{1}{b-a}\right)^n \mathbb{I}(a \leq \min_j X_j \text{ és } \max_j X_j \leq b).$$

Az első tényező legyen minél nagyobb (vagyis  $b - a$  minél kisebb) úgy, hogy a második tényező nem nulla. Ebből:

$$\hat{a} = \min_j X_j; \quad \hat{b} = \max_j X_j.$$

# Maximum-likelihood becslések

- binomiális eloszlás ismert  $k$  renddel:  $\hat{p} = \bar{X}/k$
- Poisson-eloszlás:  $\hat{\lambda} = \bar{X}$
- geometriai eloszlás:  $\hat{p} = 1/\bar{X}$
- normális eloszlás:  $\hat{m} = \bar{X}, \hat{\sigma} = s_n$
- exponenciális eloszlás:  $\hat{\lambda} = 1/\bar{X}$
- egyenletes eloszlás:  $\hat{a} = \min_j X_j; \quad \hat{b} = \max_j X_j$

# Momentum módszer ismeretlen paraméterek becslésére

Legyen  $X_1, \dots, X_n$  független azonos eloszlású minta.

- 1 Az eloszlás  $k$ . momentuma, ha  $\vartheta$  az ismeretlen paraméter:  $\mu_{k,\vartheta} = \mathbb{E}_{\vartheta}(X_1^k)$ .
- 2 Legyen  $\hat{\mu}_k = \frac{1}{n} \sum_{j=1}^n X_j^k$  az eloszlás  $k$ . tapasztalati momentuma.
- 3 Írjuk fel az alábbi egyenleteket a legkisebb olyan  $k$ -ig, amire az egyenletrendszer egyértelműen meghatározza  $\vartheta$ -t (**bár nincs mindig ilyen  $k$** ):

$$\mathbb{E}_{\vartheta}(X_1) = \frac{1}{n} \sum_{j=1}^n X_j;$$

$$\mathbb{E}_{\vartheta}(X_1^2) = \frac{1}{n} \sum_{j=1}^n X_j^2;$$

...

$$\mathbb{E}_{\vartheta}(X_1^k) = \frac{1}{n} \sum_{j=1}^n X_j^k.$$

- 4 A  $\vartheta$  momentum módszerrel kapott becslése az a  $\hat{\vartheta}$ , ami megoldása a fenti egyenletrendszernek. **Nem mindig létezik, nem mindig egyértelmű, nem feltétlenül hatásos.**

## Momentum módszer: Poisson- és exponenciális eloszlás

$X_1, \dots, X_n$  független **Poisson-eloszlásúak** ismeretlen  $\lambda > 0$  paraméterrel. A  $k = 1$ -hez tartozó egyenlet:

$$\mathbb{E}_\lambda(X_1) = \bar{X}.$$

Mivel a  $\lambda$  paraméterű Poisson-eloszlás várható értéke  $\lambda$ :

$$\hat{\lambda} = \bar{X}.$$

## Momentummódszer: Poisson- és exponenciális eloszlás

$X_1, \dots, X_n$  független **Poisson-eloszlásúak** ismeretlen  $\lambda > 0$  paraméterrel. A  $k = 1$ -hez tartozó egyenlet:

$$\mathbb{E}_\lambda(X_1) = \bar{X}.$$

Mivel a  $\lambda$  paraméterű Poisson-eloszlás várható értéke  $\lambda$ :

$$\hat{\lambda} = \bar{X}.$$

$X_1, \dots, X_n$  független **exponenciális** eloszlásúak ismeretlen  $\lambda > 0$  paraméterrel. A  $k = 1$ -hez tartozó egyenlet:

$$\mathbb{E}_\lambda(X_1) = \frac{1}{\lambda} = \frac{1}{n} \sum_{j=1}^n X_j = \bar{X}.$$

Ez egyértelműen oldható meg  $\lambda$ -ra:

$$\hat{\lambda} = \frac{1}{\bar{X}}.$$

## Momentum módszer: normális eloszlás

$X_1, \dots, X_n$  független  $N(m, \sigma^2)$  eloszlású minta (azaz normális eloszlású  $m$  várható értékkel és  $\sigma$  szórással).

A  $k = 1$ -hez és  $k = 2$ -höz tartozó egyenletek:

$$\mathbb{E}_{m,\sigma}(X_1) = m = \bar{X};$$

$$\mathbb{E}_{m,\sigma}(X_1^2) = \sigma^2 + m^2 = \frac{1}{n} \sum_{j=1}^n X_j^2.$$

A másodikba beírva az elsőt:  $\sigma^2 = \frac{1}{n} \sum_{j=1}^n X_j^2 - \bar{X}^2 = s_n^2$  (a tapasztalati szórásnégyzet). Tehát az első két egyenlet együtt egyértelműen oldható meg, a momentum módszerrel kapott becslés:

$$\hat{m} = \bar{X}; \quad \hat{\sigma} = s_n.$$

## Momentum módszer: egyenletes eloszlás

Legyen  $X_1, \dots, X_n$  független minta az  $[a, b]$  intervallumon egyenletes eloszlásból. Ennek várható értéke  $(a + b)/2$ , szórása  $(b - a)/\sqrt{12}$ . Ezek alapján a  $k = 1$ -hez és  $k = 2$ -höz tartozó egyenlet:

$$\mathbb{E}_{a,b}(X_1) = \frac{a + b}{2} = \bar{X};$$
$$\mathbb{E}_{a,b}(X_1^2) = \frac{(b - a)^2}{12} + \left(\frac{a + b}{2}\right)^2 = \frac{1}{n} \sum_{j=1}^n X_j^2.$$

A másodikba beírva az elsőt:  $\frac{(b-a)^2}{12} = \frac{1}{n} \sum_{j=1}^n X_j^2 - \bar{X}^2 = s_n^2$ , amiből

$$\hat{a} = \bar{X} - \sqrt{3}s_n; \quad \hat{b} = \bar{X} + \sqrt{3}s_n.$$

# Elégséges statisztika

## Definíció

Legyen  $X_1, \dots, X_n$  független minta  $\vartheta$  paraméterű eloszlásból. A  $T$  statisztika elégséges, ha a likelihood-függvény felírható a következő alakban megfelelő  $h$  és  $g$  függvényekkel:

$$L_{n,\vartheta}(X_1, \dots, X_n) = h(X_1, \dots, X_n) \cdot g_{\vartheta}(T(X_1, \dots, X_n)).$$

# Elégséges statisztika

## Definíció

*Legyen  $X_1, \dots, X_n$  független minta  $\vartheta$  paraméterű eloszlásból. A  $T$  statisztika elégséges, ha a likelihood-függvény felírható a következő alakban megfelelő  $h$  és  $g$  függvényekkel:*

$$L_{n,\vartheta}(X_1, \dots, X_n) = h(X_1, \dots, X_n) \cdot g_{\vartheta}(T(X_1, \dots, X_n)).$$

Például a Poisson-eloszlás esetén  $T(X_1, \dots, X_n) = \bar{X}$ , normális eloszlás esetén  $T(X_1, \dots, X_n) = (\bar{X}, s_n^2)$  elégséges statisztika.

Az elégséges statisztika nem egyértelmű.

Ha létezik ML-beclés,  $T$  pedig elégséges statisztika, akkor az ML-beclés felírható  $s(T(X_1, \dots, X_n))$  alakban valamely  $s$  függvényre.

# Rao–Blackwell-tétel

## Tétel (Rao–Blackwell)

*Tegyük fel, hogy a  $T$  statisztika torzítatlan becslés a  $\vartheta$  paraméterre, valamint  $S$  elégséges statisztika  $\vartheta$ -ra. Ekkor megadható olyan  $T^*$  becslés, melyre*

- $T^* = h(S)$  megfelelő  $h$  függvénnyel;
- $T^*$  torzítatlan  $\vartheta$ -ra:  $\mathbb{E}_{\vartheta}(T^*) = \vartheta$  minden  $\vartheta \in \Theta$ -ra;
- $T^*$  hatásosabb, mint  $T$ :  $D_{\vartheta}(T^*) \leq D_{\vartheta}(T)$  minden  $\vartheta \in \Theta$ -ra.

*Ha az  $S$  statisztika teljes is (azaz minden olyan  $f$  függvény, melyre  $\mathbb{E}_{\vartheta}(f(S)) = 0$  minden  $\vartheta$ -ra, „majdnem mindenütt” nulla), akkor  $T^*$  hatásos, azaz minden torzítatlan becslésnél hatásosabb.*

A megoldás az  $\mathbb{E}(T|S)$  feltételes várható érték lesz.

## Állítás

*Poisson, exponenciális, normális eloszlásoknál ( $m$ -re) a mintaelemek összege teljes elégséges statisztika, a mintaátlag pedig hatásos becslése a paraméternek.*

# Fisher-információ

Egy mintaelem **Fisher-információja**:

$$I_1(\vartheta) = \mathbb{E}_{\vartheta} \left( \left( \frac{\partial}{\partial \vartheta} \log f_{\vartheta}(X_1) \right)^2 \right),$$

ahol  $f_{\vartheta}$  a sűrűségfüggvény  $\mathbb{P}_{\vartheta}$  mellett.

# Fisher-információ

Egy mintaelem **Fisher-információja**:

$$I_1(\vartheta) = \mathbb{E}_{\vartheta} \left( \left( \frac{\partial}{\partial \vartheta} \log f_{\vartheta}(X_1) \right)^2 \right),$$

ahol  $f_{\vartheta}$  a sűrűségfüggvény  $\mathbb{P}_{\vartheta}$  mellett.

- Megfelelő (regularitási) feltételek mellett a független azonos eloszlású,  $n$  elemű minta Fisher-információja:  $I_n(\vartheta) = n \cdot I_1(\vartheta)$ .
- Ha  $T$  elégséges statisztika, akkor  $T(X_1, \dots, X_n)$  Fisher-információja ugyanaz, mint  $(X_1, \dots, X_n)$  Fisher-információja (például Poisson-eloszlásnál az átlag Fisher-információja ugyanaz, mint a teljes mintáé).
- **Cramér–Rao-egyenlőtlenség**: megfelelő (regularitási) feltételek mellett, ha  $T$  torzítatlan becslés  $\vartheta$ -ra, akkor

$$D^2(T(X)) \geq \frac{1}{I_n(\vartheta)} = \frac{1}{nI_1(\vartheta)}.$$

(Ebben az értelemben feleakkora szóráshoz négyszer annyi mintaelem kell.)